

Sveučilište Jurja Dobrile u Puli

Fakultet ekonomije i turizma

„Dr. Mijo Mirković“

ADAM VUKELIĆ

Primjena MPT modela na hrvatskom tržištu kapitala

Završni rad

Pula, 2016. godina

Sveučilište Jurja Dobrile u Puli

Fakultet ekonomije i turizma

„Dr. Mijo Mirković“

ADAM VUKELIĆ

Primjena MPT modela na hrvatskom tržištu kapitala

Završni rad

JMBAG: 0303028092, redoviti student

Studijski smjer: Financijski management

Predmet: Financijska tržišta

Mentor: Izv. prof. dr. sc. Dean Učkar

Pula, studeni 2016. godine



IZJAVA O AKADEMSKOJ ČESTITOSTI

Ja, dolje potpisani Adam Vukelić, kandidat za prvostupnika ekonomije ovime izjavljujem da je ovaj Završni rad rezultat isključivo mogega vlastitog rada, da se temelji na mojim istraživanjima te da se oslanja na objavljenu literaturu kao što to pokazuju korištene bilješke i bibliografija. Izjavljujem da niti jedan dio Završnog rada nije napisan na nedozvoljen način, odnosno da je prepisan iz kojega necitiranog rada, te da ikoji dio rada krši bilo čija autorska prava. Izjavljujem, također, da nijedan dio rada nije iskorišten za koji drugi rad pri bilo kojoj drugoj visokoškolskoj, znanstvenoj ili radnoj ustanovi.

Student:

U Puli, 09.11.2016. godine



IZJAVA

o korištenju autorskog djela

Ja, Adam Vukelić dajem odobrenje Sveučilištu Jurja Dobrile u Puli, kao nositelju prava iskorištavanja, da moj završni rad pod nazivom „Primjena MPT modela na hrvatskom tržištu kapitala“ koristi na način da gore navedeno autorsko djelo, kao cjeloviti tekst objavi u javnoj internetskoj bazi Sveučilišne knjižnice Sveučilišta Jurja Dobrile u Puli te kopira u javnu internetsku bazu završnih radova Nacionalne i sveučilišne knjižnice (stavljanje na raspolaganje javnosti), sve u skladu s Zakonom o autorskom pravu i drugim srodnim pravima i dobrom akademskom praksom, a radi promicanja otvorenoga, slobodnoga pristupa znanstvenim informacijama.

Za korištenje autorskog djela na gore navedeni način ne potražujem naknadu.

U Puli, 09.11.2016. godine

Potpis

SADRŽAJ

1. Uvod.....	1
2. Karakteristike Markowitzevog modela.....	2
3. Upravljanje portfeljem.....	4
4. Efikasna granica.....	7
4.1. Krivulja korisnosti.....	9
4.2. Optimalan portfelj za pojedinačnog investitora.....	10
5. Empirijsko testiranje MPT modela na hrvatskom tržištu kapitala.....	12
5.1. Definiranje uzorka.....	12
5.2. Rezultati empirijskog testiranja.....	19
6. Zaključak.....	24
Literatura.....	25
Sažetak.....	27
Summary.....	28

1. UVOD

U ovom završnom radu govoriti će se o ulozi Markowitzevog modela i njegovom utjecaju na stvaranje efikasnih portfelja čija je primjena moguća i u današnjici iako je on svoj rad objavio prije nešto manje od pedeset godina. Cilj rada je dokazivanje primjenjivosti Markowitzevog modela na odabranim dionicama sa hrvatskog tržišta kapitala. Usmjerenost rada biti će na definiranju ključnih pojmova vezanih uz portfelj i njegovo upravljanje dok je svrha ovog istraživanja stvaranje efikasnog portfelja koristeći dionice koje čine sastav CROBEX – a.

U prvom poglavlju definirati će se karakteristike i osnovne pretpostavke vezane uz Markowitza i njegovu modernu teoriju portfelja. U nastavku rada obrađena je diverzifikacija i njena važnost te njen doprinos stvaranju i upravljanju portfeljem. Isto tako, važno je napomenuti da se različiti investitori različito ponašaju na tržištu kapitala pa će tako njihova sklonost prema riziku utjecati na stvaranje različitih optimalnih portfelja. Budući da je rizik u odnosu sa prinosom, dok ga pojedini investitori izbjegavaju, drugi ga prihvataju jer sa preuzimanjem većih rizika postižu se i veći prinosi.

U četvrtom poglavlju obrađen je pojam efikasnog portfelja, odnosno pojam efikasne granice te njen izgled. Cilj svakog racionalnog investitora je ostvariti što veći prinos preuzimanjem što nižeg rizika, a pronalazak baš takve kombinacije smješten je na krivulji efikasne granice. Uz nju se veže i krivulja korisnosti koja prikazuje kolika je korisnost ulaganja za investitora u odnosu na rizik.

Nakon teorijskog dijela slijedi praktični gdje će biti prikazana kretanja vrijednosti dionica preuzetih sa Zagrebačke burze. U sklopu petog i šestog poglavlja prikazane su odabrane dionice i njihovi izračuni godišnjih prosječnih cijena dionica, godišnjih prosječnih stopa prinosa, te kroz uzorak udjeli dionica u stvorenom optimalnom portfelju.

U radu su korištene sljedeće znanstveno – istraživačke metode: statistička i matematička metoda, induktivna i deduktivna metoda, povijesna metoda, metoda analize i metoda sinteze.

2. KARAKTERISTIKE MARKOWITZEVOG MODELA

Američki nobelovac, profesor Harry Max Markowitz je svojim radom iz 1952. godine postao tvorac moderne portfelj teorije. Njegov cilj je bio razviti teoriju odnosno model prema kojem će prinos i rizik biti u ravnoteži pri kvalitetnoj kombinaciji vrijednosnica unutar određenog portfelja. Taj je cilj i postigao, te ga pojasnio unutar svoje knjige „Portfolio Selection: Efficient Diversification of Investments“ koja je objavljena 1959. godine (Markowitz, 1959.). Time je postigao stvaranje portfelja koji će za neku određenu razinu prinosa imati minimalan stupanj rizika, odnosno stvaranje portfelja koji će pri određenom stupnju rizika donositi najveći mogući prinos/prihod.

Markowitzev model optimizacije portfelja, poznatiji kao MV model (engl. mean – variance model) visoko je vrednovan, a to se i očituje u činjenici da je za svoja postignuća u razvoju moderne teorije portfelja 1990. godine dobio Nobelovu nagradu iz ekonomije. Osnovna Markowitzeva ideja bila je pronalazak ravnoteže između rizika i prihoda, te odabrati portfelj dionica koji donosi najveću moguću dobit uz najmanji mogući rizik (Aljinović, Marasović i Šego, 2008., str. 133). Cilj modernog upravljanja portfeljom je optimizacija odnosa očekivanog prihoda i pripadajućeg rizika, te se on kao takav veže s izrazom „Nije dobro držati sva jaja u jednoj košari“. Tom izjavom se želi reći da investiranjem u više različitih vrijednosnica (npr. različiti tipovi imovine, različite grane industrija) smanjuje se rizik portfelja budući da se različita financijska tržišta kreću u različitim smjerovima.

Budući da većina investitora želi smanjiti što je više moguće stupanj rizika prilikom odabira dviju ili više različitih dionica, uz pretpostavku da svaka postiže isti prinos, investitori će odabrati onu koja nosi manji rizik. Isto tako, ako je cilj investitora ostvarenje maksimalnog mogućeg prinosa on će morati biti spreman pristati na preuzimanje većeg rizika kako bi isti i ostvario. Iz prethodno navedenog može se zaključiti da će racionalan investitor prilikom odabira između dva ili više portfelja uvijek odabrati onaj koji mu za isti ili približno sličan stupanj rizika nosi što je moguće veći očekivani prinos. Što je investitor spremniji prihvatiti veći stupanj rizika to je veća i vjerojatnost da će ostvariti značajniji prinos. Od tuda proilazi glavna pretpostavka

ovog modela da investitori nisu skloni preuzimanju većeg rizika ukoliko za to nisu nagrađeni većom zaradom.

„Osnovne pretpostavke Markowitzevog modela (Jerončić i Aljinović, 2011., str. 585):

- prinosi na dionice su distribuirani po normalnoj distribuciji,
- investitori žele maksimizirati svoju ekonomsku korisnost,
- investitori su racionalni i imaju averziju prema riziku,
- investitori su dobro obaviješteni o svim relevantnim činjenicama potrebnima za donošenje investicijske odluke,
- nema transakcijskih i poreznih troškova,
- vrijednosnice su savršeno djeljive.

Također je pretpostavljeno da investitor ima slobodan izbor od N rizičnih vrijednosnica s poznatim očekivanim prinosom, varijancom i standardnom devijacijom, kao i matricom njihovih varijanci i kovarijanci.“

Markowitz je osvojio brojne pohvale i nagrade za svoj model (koji uključuje gore navedene pretpostavke), ali se trebao nositi i sa kritikama. Ovaj model iako ima dosta prepreka i dalje je funkcionalan, odnosno i dalje je primjenjiv. Glavna prepreka su prinosi na dionice koji ne mogu uvijek biti normalno distribuirani, a pogotovo ne za vrijeme gospodarskog pada ili uzleta. Isto tako, investitori nisu uvijek racionalni niti postupaju racionalno. Određeni investitori uopće ne izbjegavaju rizik, već su mu skloni. Kvalitetna i pravovremena informiranost također čini prepreku radi asimetrije informacija i radi vremena u kojoj je informacija poznata ulagaču. Vrijednosnice nisu savršeno djeljive, a transakcijski i porezni troškovi su dio prepreka koje ovaj model sadrži u praksi. Maksimizacija korisnosti investitora je jedina pretpostavka koja je zapravo realna, budući da svaki investitor želi ostvariti čim veći prinos na svoje ulaganje (Jerončić i Aljinović, 2011., str. 587).


3. UPRAVLJANJE PORTFELJEM

Portfelj se može definirati kao kombinacija dviju ili više vrijednosnica ili drugih vrsta imovine koje drži određeni pojedinac ili kompanija. Uz pojam portfelja također je vezan i pojam diverzifikacije koji predstavlja kombinaciju vrijednosnica na način da se umanjuje relativni rizik. Kombiniranjem imovine u portfelju postiže se smanjenje rizika portfelja (ako su imovine manje nego perfektno pozitivno korelirane) na način da dio rizika jedne imovine poništava dio rizika druge imovine (Vidučić, 2006., str. 74). Sukladno tome racionalni investitori će uvijek težiti stvaranju diverzificiranog portfelja jer je takav portfelj puno stabilniji i sigurniji od onoga koji se sastoji od vrijednosnica samo jedne industrije ili poduzeća. Ukoliko investitor posjeduje dionice samo jednog poduzeća i njihova vrijednost padne, automatski je vrijednost portfelja niža te je investitor na gubitku. Međutim, ako investitor posjeduje više dionica različite imovine i različitih industrija, pad vrijednosti jedne dionice će moći nadomjestiti rastom ili makar manjim padom ostalih dionica unutar portfelja te će samim time završni rezultat biti uspješniji. Različiti investitori različito djeluju na tržištu kapitala pa će tako visina rizika koju će određeni investitor prihvatiti ovisiti o njegovim preferencijama. Oni koji nisu skloni prihvaćanju velikog rizika spremniji su prihvatiti niži prinos kako bi sačuvali sigurnost, dok agresivniji investitori koji žele veći prinos moraju biti spremni isto tako prihvatiti veći rizik.

Rizik se može definirati kao odstupanje stvarnog od očekivanog prinosa. Što je to odstupanje veće to je vrijednosnica rizičnija. Kada je riječ o riziku unutar portfelja važno je znati da se ukupni rizik djeli na sistemski (tržišni) i nesistemski. Nesistemski rizik je moguće umanjiti diverzifikacijom dok na sistemski (tržišni) je teže utjecati budući da on ovisi o kretanju tržišta odnosno ovisi o kretanju vrijednosnica na ukupnom tržištu kapitala. Primjerice, na sistemski rizik utječu promjene u nacionalnom gospodarstvu, donošenje poreznih reformi ili neke promjene u svjetskoj energetskej situaciji i one ostavljaju utjecaj na sve vrijednosnice pa tako diverzifikacija ne može izbjeći ovaj rizik. S druge strane, nesistemski rizik je jedinstven za određeno poduzeće ili određenu djelatnost, a ovisi o ekonomskim, političkim i ostalim faktorima što utječu na sve vrijednosnice, ali u smislu tog sustava (Van Horne i Wachowicz, JR., 2002.).

Budući da rizik portfelja ovisi o broju dionica uvrštenih u portfelj i o njihovom koeficijentu korelacije, smanjenje rizika se postiže povećanjem broja dionica pa će tako interes investitora biti usmjeren na prinos i rizik svih dionica unutar portfelja, a ne samo na pojedine dionice. Na slici 1. jasno se primjećuje kako se stupanj rizika portfelja (σ_p) smanjuje sukladno rastu broja dionica u portfelju (N).

Slika 1.



Izvor: JAKŠIĆ, S. (2007.) Primjena Markowitzove teorije na tržište dionica Zagrebačke burze. Zagreb: Ekonomski fakultet Zagreb, str. 334

Dva temeljna parametra procjene ukupnog rizika bilo koje investicije, odnosno bilo koje imovine kada se rizik ocjenjuje iz ukupne distribucije vrijednosti su (Orsag, 2015., str. 240):

- očekivana vrijednost,
- varijanca, odnosno standardna devijacija.

Rizik portfelja je obrnuto proporcionalan s brojem vrijednosnica u portfelju, a proporcionalan s koeficijentom korelacije¹. Odnosno, manji je što je veći broj vrijednosnica u portfelju i što je manji koeficijent korelacije (Vidučić, 2006., str. 76). Rizičnost portfelja se povećava ukoliko je unutar istoga pozitivna korelacija između vrijednosnica. Ako su vrijednosnice unutar portelja pozitivno korelirane onda je njihova kretnja zajednička pa tako i njihov negativni ili pozitivni povrat ujednačen. Međutim, negativna korelacija među vrijednosnicama je pozitivan pokazatelj jer se onda one ne kreću zajedno pa tako negativni povrat jedne vrijednosnice ujedno podrazumijeva pozitivan povrat druge vrijednosnice. Primjerice, ako je koeficijent korelacije +1, onda su prinosi savršeno pozitivno korelirani pa u slučaju rasta prinosa jedne dionice raste i prinos druge dionice (i obrnuto u slučaju pada prinosa), a ako je koeficijent korelacije -1 onda su prinosi savršeno negativno korelirani pa će rast prinosa jedne dionice utjecati na pad prinosa druge dionice u toj vrijednosti (i obrnuto). U praksi koeficijent korelacije se kreće između ta dva intervala. Što je broj imovine veći u određenom portfelju to je njegova rizičnost manja pri čemu umanjenje rizika ovisi o stupnju korelacije imovine. Vlasnici dobro diverzificiranih portfelja svijesni su da pojedinačne imovine nisu savršeno korelirane jedna s drugom te je tako njihova rizičnost portfelja niža.

Standardna devijacija je statistička mjera odstupanja razdiobe od njezine sredine, a ona je zapravo kvadratni korijen varijance. Što je standardna devijacija prinosa veća, odstupanje prinosa je veće, pa je tako i rizik investicije veći. Standardna devijacija portfelja ne ovisi samo o varijanci pojedinih vrijednosnica, nego i o kovarijanci² između različitih vrijednosnica koje se stavljaju u parove. Kako broj vrijednosnica raste u portfelju, kovarijančni odnosi postaju važniji prema varijančnim odnosima (Van Horne i Wachowicz, JR., 2002., str. 91-97). Standardna devijacija povrata na pojedinačnu dionicu prikazuje investitoru koliko bi bila rizična ta dionica ukoliko bi on ulagao samo u nju, ali investitora zanima koliko svaka dionica utječe na ukupni rizik portfelja. Pojedina dionica doprinosi u ukupnom riziku portfelja ovisno o tome koliko povrati dionice variraju u odnosu na druge dionice. Ukoliko povrati pojedine rizične dionice ne idu u korak s ostatkom portfelja investitor ju ne može koristiti za smanjenje varijabilnosti portfelja (Brealey, Myers i Marcus, 2007., str. 280).


¹ Koeficijent korelacije se može kretati u intervalu od -1 do +1, a govori o smjeru i intenzitetu povezanosti između varijabli.

² Kovarijanca prikazuje očekivano variranje dviju vrijednosnica jedne s drugom.

4. EFIKASNA GRANICA

Efikan portfelj je upravo onaj koji između svih kombinacija koje donose isti prinos ima najniži rizik, odnosno koji između svih kombinacija istog stupnja rizika donosi najviši prinos. Drugim riječima, efikan portfelj dominira naspram drugih kombinacija investicija ili sa stajališta prinosa ili sa stajališta rizika, te će radi toga svaki racionalni investitor izabrati samo između efikasnih portfelja (Orsag, 2015., str. 260).

Slika 2.



Izvor: ORSAG, S. (2015.) Investicijska analiza. Zagreb: Avantis, str. 264

Za portfelje prikazane na slici 2. efikasan skup kombinacija investicija smješten je na gornjoj lijevoj granici skupa mogućih portfelja, to jest na sjeverozapadnoj granici skupa mogućih portfelja (BCDE). Navedeni se skup portfelja naziva efikasnom granicom, a on predstavlja one kombinacije investicija koje bi odabrao određeni racionalni investitor budući da dominiraju prema svim drugim kombinacijama ili sa stajališta rizika ili sa stajališta očekivanog prinosa. Međutim, lijevo iza efikasne granice ne nalaze se moguće kombinacije investicija jer ne postoji portfelj investicija koji bi obećavao viši prinos uz manji rizik (Orsag, 2015., str. 264).

„Skup mogućih portfelja čine svi oni portfelji koji se mogu sastaviti od N zadanih rizičnih vrijednosnica. Svaki portfelj karakteriziran je svojim (očekivanim) prinosom i svojim rizikom (varijancom prinosa ili standardnom devijacijom)“ (Jerončić i Aljinović, 2011., str. 585). Markowitz je zaključio da ukupan portfelj ne smije biti više rizičan nego svaka pojedinačna vrijednosnica unutar istoga, te je tako dokazao da vrijedi diverzificirati kako bi se ukupan rizik portfelja umanjio budući da se cijene dionica ne kreću istim smjerom u potpunosti. Diverzifikacija postiže najbolji učinak kada su povrati u negativnoj korelaciji (Brealey, Myers i Marcus, 2007., str. 280).

4.1. KRIVULJA KORISNOSTI

Korisnost predstavlja ostvareni prinos za investitora, te kao takva ovisi o odnosu rizika i prinosa. Ona ima funkciju subjektivne vrijednosti jer nešto što određenom investitoru predstavlja značajnu korisnost drugom nužno ne mora. Kada investitor donosi odluku o izboru vrijednosnica koje će sačinjavati njegov portfelj on uvijek prati korisnost koju će mu donositi pojedina vrijednosnica. Prilikom odabira vrijednosnica veću značajnost za investitora će uvijek imati ona koja za isti prinos nosi manji stupanj rizika, odnosno ona koja mu donosi najveću korisnost.

Funkcija korisnosti $U(W)$ trebala bi biti rastućeg oblika, odnosno racionalan investitor će u svakom slučaju odabrati situaciju u kojoj može ostvariti veći prinos naspram one u kojoj će ostvariti manji prinos uz pretpostavku da su opcije jednako vjerojatne (Tomić – Plazibat, Aljinović i Marasović, 2006., str. 8). Investitorova sklonost prema riziku određuje oblik funkcije potražnje.


Ovisno o sklonostima investitora postoje tri oblika funkcije korisnosti:

- kod pojedinca indiferentnog prema riziku funkcija korisnosti prikazana je pravcem (linearna veza),
- kod pojedinca sklonog preuzimanju rizika funkcija korisnosti je konveksna (rastući nagib),
- kod pojedinca nesklonog preuzimanju rizika funkcija korisnosti je konkavna (padajući nagib).

Na slici 4. jasno se vidi da će investitor koji je sklon riziku prije riskirati svoje ukupno bogatstvo kako bi ostvario priliku za ostvarenjem velikog dobitka pa tako njegova krivulja ima rastuću graničnu korisnost. Investitora koji nije sklon riziku, ulaganje svojeg ukupnog bogatstva radi većeg dobitka ne privlači jer nije spreman prihvatiti takav rizik radi vjerojatnosti velikog gubitka pa tako njegova krivulja ima padajuću korisnost. Kod investitora indiferentnog prema riziku krivulja korisnosti je prikazana pravcem što znači da će biti spreman prihvatiti rizik ulaganja svojeg bogatstva sukladno mogućnosti ostvarenja korisnosti.

Slika 4.

Funkcije korisnosti ovisne o sklonostima investitora



Izvor: TOMIĆ – PLAZIBAT, N., ALJINOVIĆ, Z. i MARASOVIĆ, B. (2006.)
Matematički modeli u financijskom upravljanju. Split: Ekonomski fakultet Split, str. 12

4.2. OPTIMALAN PORTFELJ ZA POJEDINAČNOG INVESTITORA

Izbor najbolje investicije najvišom krivuljom indiferencije³ odgovara i izboru optimalnog portfelja određenog investitora. Sastavljajući portfelj investitor može iskoristiti princip diverzifikacije kojim će reducirati određeni dio specifičnog rizika. Radi toga u portfelju može postići povoljniji odnos rizika i nagrade nego što bi imao odabirom najbolje individualne investicije. Već je ranije utvrđeno kako se unutar određenog broja pojedinačnih investicija za sve investitore najbolji skup portfelja tih investicija nalazi na efikasnoj granici budući da dominiraju u odnosu na sve ostale kombinacije prinosom ili rizikom, odnosno uz danu razinu prinosa imaju najmanji rizik i za danu razinu rizika imaju najviši prinos (Orsag, 2015., str. 282).

³ Krivulja indiferencije pokazuje povezanost između investitorove averzije prema riziku i prihvatljive premije rizika. Na njoj se nalaze sve kombinacije investicija koje imaju identičnu korisnost za određenog investitora.

Optimalan portfelj je onaj portfelj koji će stvoriti najveću korisnost za svog investitora, odnosno to je portfelj koji pri određenoj stopi rizika donosi maksimalni prinos investitoru pa se tako njegovo mjesto nalazi na dodiru krivulje indiferencije i efikasne granice. Svaki investitor gradi portfelj koji odgovara njegovim preferencijama i sklonostima prihvatanja rizika pa se tako s različitim investitorima stvaraju različiti optimalni portfelji. Cilj investitora je uravnoteženje rizika i prihoda koji su u skladu s njegovim sklonostima u kombinaciji odabranih vrijednosnica.

Koristeći se Markowitzevim modelom, ulagač iz skupa svih mogućih portfelja izabire onaj portfelj (efikasni portfelj) čiji je odnos očekivanog prinosa i očekivanog rizika odgovara njegovoj osobnoj ulagačkoj filozofiji. „Harry Markowitz je pretpostavio sljedeće (Raić, 2015.):

- rizik portfelja baziran je na varijabilnosti prinosa istog portfelja;
- investitor ima averziju prema riziku;
- investitor ima preferenciju ka potrošnji i njenom rastu;
- krivulja korisnosti investitora je rastuća i konkavna;
- investitor maksimizira prinos portfelja uz danu razinu rizika, ili minimizira rizik uz danu razinu prinosa;
- analiza se bazira na modelu jednog razdoblja investiranja;
- investitor je po prirodi racionalan.“

5. EMPIRIJSKO TESTIRANJE MPT MODELA NA HRVATSKOM TRŽIŠTU KAPITALA

5.1. DEFINIRANJE UZORKA

Odabrane dionice indeksa CROBEX preuzete su sa stranice Zagrebačke burze te su prikazane pomoću tablice. U tablici 1. prikazane su oznake i nazivi društva za odabrane redovne dionice hrvatskog tržišta kapitala koje su činile sastav CROBEX – a na dan 01.09.2016. godine, te su tada u indeksu CROBEX – a bile izlistane 23 dionice.

CROBEX je vrsta cjenovnog indeksa čija se revizija odvija polugodišnje, te se u njegov izračun ne uključuju isplaćene dividende. Društvo mora trgovati minimalno 80% dana u godini kako bi dionica bila izlistana u indeksu CROBEX – a, međutim društva u kojima je pokrenut stečajni postupak ili postupak likvidacije iako zadovoljavaju uvjet broja trgovinskih dana ne mogu ući u sustav indeksa. Najveća težina koju neka dionica u indeksu može imati je 10%, a maksimalan broj dionica u indeksu je 25.

U analizirani uzorak su uvrštene dionice indeksa CROBEX jer su zadovoljile kriterije najlikvidnijih i najtransparentnijih dionica na hrvatskom tržištu kapitala. Kroz nastavak poglavlja biti će prikazane godišnje prosječne cijene i godišnje prosječne stope prinosa za odabrana društva tijekom 2014. i 2015. godine. Odabranih 22 društva su⁴: (<http://zse.hr/>)

⁴ U odabrana društva ne spadaju dionice Adris grupe d.d. jer su one povlaštene dionice i kao takve se razlikuju od ostalih dionica koje sve spadaju u grupu redovnih dionica.

Tablica 1.

Dionice CROBEX – a

OZNAKA	DRUŠTVO	OZNAKA	DRUŠTVO
ADPL-R-A	AD Plastik d.d.	KOEI-R-A	Končar – Elektroindustrija d.d.
ARNT-R-A	Arenaturist d.d.	KRAS-R-A	Kraš d.d.
ATGR-R-A	Atlantic Grupa d.d.	LEDO-R-A	Ledo d.d.
ATPL-R-A	Atlantska plovidba d.d.	LKRI-R-A	Luka Rijeka d.d.
BLJE-R-A	Belje d.d. Darda	MAIS-R-A	Maistra d.d.
DDJH-R-A	Đuro Đaković Holding d.d.	OPTE-R-A	Ot – Optima Telekom d.d.
DLKV-R-A	Dalekovod d.d.	PODR-R-A	Podravka d.d.
ERNT-R-A	Ericsson Nikola Tesla d.d.	RIVP-R-A	Valamar Riviera d.d.
HT-R-A	Hrvatski Telekom d.d.	TPNG-R-A	Tankerska Next Generation d.d.
INA-R-A	INA – industrija nafte d.d.	VART-R-1	Varteks d.d.
INGR-R-A	Ingra d.d.	ZABA-R-A	Zagrebačka banka d.d.

Izvor: <http://zse.hr/default.aspx?id=44101&index=CROBEX> [Pristupljeno 01.09.2016]

Tablica 2.

Prikaz prosječnih godišnjih cijena odabranih društva za 2014. godinu

<u>RB</u>	<u>DIONICA</u>	<u>PROSJEČNA CIJENA (kn)</u>
1	ADPL-R-A	118,33
2	ARNT-R-A	297,40
3	ATGR-R-A	879,45
4	ATPL-R-A	356,85
5	BLJE-R-A	41,51
6	DDJH-R-A	43,35
7	DLKV-R-A	22,12
8	ERNT-R-A	1451,28
9	HT-R-A	158,88
10	INA-R-A	3652,73
11	INGR-R-A	2,63
12	KOEI-R-A	687,70
13	KRAS-R-A	353,05
14	LEDO-R-A	8603,64
15	LKRI-R-A	78,20
16	MAIS-R-A	114,53
17	OPTE-R-A	5,72
18	PODR-R-A	295,77
19	RIVP-R-A	16,85
20	TPNG-R-A	bez trgovanja
21	VART-R-1	21,28
22	ZABA-R-A	31,70

Izvor: izračun autora

U 2014. godini društvo Ledo d.d. ima najveću prosječnu cijenu dionica u iznosu od 8603,64 kune, a slijede ga Ina d.d. i Ericsson Nikola Tesla d.d. Najnižu prosječnu cijenu dionica ima društvo Ingra d.d. u vrijednosti od 2,63 kune. Društvo Tankerska Next Generation d.d. je uvršteno u tablicu iako nije trgovalo dionicama u 2014. godini te nije bilo uvršteno na burzu, ali analiza unutar rada je bazirana na 2015 – oj godini u kojoj su obavljali trgovinu dionicama.

Tablica 3.

Prikaz prosječnih godišnjih cijena odabranih društva za 2015. godinu

<u>RB</u>	<u>DIONICA</u>	<u>PROSJEČNA CIJENA (kn)</u>
1	ADPL-R-A	96,00
2	ARNT-R-A	336,36
3	ATGR-R-A	880,12
4	ATPL-R-A	216,15
5	BLJE-R-A	27,56
6	DDJH-R-A	28,10
7	DLKV-R-A	15,92
8	ERNT-R-A	1181,06
9	HT-R-A	153,35
10	INA-R-A	3424,02
11	INGR-R-A	3,11
12	KOEI-R-A	680,42
13	KRAS-R-A	434,25
14	LEDO-R-A	8410,87
15	LKRI-R-A	51,67
16	MAIS-R-A	202,71
17	OPTE-R-A	2,12
18	PODR-R-A	315,46
19	RIVP-R-A	21,38
20	TPNG-R-A	73,18
21	VART-R-1	18,19
22	ZABA-R-A	37,28

Izvor: izračun autora

Prikazani podaci (tablica 2. i 3.) postignuti su tako što su preuzete cijene dionica sa Zagrebačke burze obrađene sa dnevne na tjednu razinu te je kasnije pomoću tih očitavanja na kraju godine izračunat prosjek svih tjednih prosječnih cijena tijekom 2015. godine. Pregledom tablice jasno je vidljivo kako kretanje najvećih godišnjih prosječnih cijena dionica postižu društva Ledo d.d., INA d.d. i Ericsson Nikola Tesla d.d., dok najniže godišnje prosječne cijene postižu društva Ot – Optima

Telekom d.d., Ingra d.d. i Dalekovod d.d. Prateći kretanje godišnjih prosječnih cijena vidi se kako su ista društva ostvarila najviše i najniže cijene u prikazanom razdoblju.

Tablica 4.

Prosječne stope prinosa dionica CROBEX – a za 2014. godinu

<u>RB</u>	<u>DIONICA</u>	<u>STOPA PRINOSA</u>
1	ADPL-R-A	0,040390
2	ARNT-R-A	0,019876
3	ATGR-R-A	0,007827
4	ATPL-R-A	0,016454
5	BLJE-R-A	0,090150
6	DDJH-R-A	0,089827
7	DLKV-R-A	0,144970
8	ERNT-R-A	0,005042
9	HT-R-A	0,031940
10	INA-R-A	0,002268
11	INGR-R-A	0,365068
12	KOEI-R-A	0,009531
13	KRAS-R-A	0,016701
14	LEDO-R-A	0,001035
15	LKRI-R-A	0,055806
16	MAIS-R-A	0,041268
17	OPTE-R-A	0,309039
18	PODR-R-A	0,019304
19	RIVP-R-A	0,170604
20	TPNG-R-A	/
21	VART-R-1	0,146353
22	ZABA-R-A	0,105819

Izvor: izračun autora

Godine 2014. društvo Ingra d.d. ima najveću prosječnu stopu prinosa od 36,51%, te ga slijedi društvo Ot – Optima Telekom d.d. sa stopom od 30,90%, dok najnižu stopu prinosa od 0,10% ima društvo Ledo d.d.

Tablica 5.

Prosječne stope prinosa dionica CROBEX – a za 2015. godinu

<u>RB</u>	<u>DIONICA</u>	<u>STOPA PRINOSA</u>
1	ADPL-R-A	0,047977
2	ARNT-R-A	0,017261
3	ATGR-R-A	0,007576
4	ATPL-R-A	0,026014
5	BLJE-R-A	0,121729
6	DDJH-R-A	0,120927
7	DLKV-R-A	0,174116
8	ERNT-R-A	0,006046
9	HT-R-A	0,032856
10	INA-R-A	0,002345
11	INGR-R-A	0,365440
12	KOEI-R-A	0,009603
13	KRAS-R-A	0,014106
14	LEDO-R-A	0,001060
15	LKRI-R-A	0,077799
16	MAIS-R-A	0,027113
17	OPTE-R-A	0,321025
18	PODR-R-A	0,017948
19	RIVP-R-A	0,143904
20	TPNG-R-A	0,052587
21	VART-R-1	0,160852
22	ZABA-R-A	0,095586

Izvor: izračun autora

U tablici 4. i 5. su prikazane godišnje prosječne stope prinosa za odabrana društva, a rezultati su postignuti korištenjem jednadžbe:

$$R_i = \ln (\text{završna cijena} + \text{dividenda}) / \text{početna cijena} \quad (1)$$

Rezultati su postignuti na način da je za gore navedenu logaritamsku jednadžbu korištena početna i završna cijena svakog tjedna (najmanje 46, a najviše

53 očitavanja za svaku dionicu) i uvrštene su vrijednosti dividende u tjedan kada je isplaćena te su potom izračunati prosjeci svih tjedana na godišnjoj razini. Dividendu u 2015. godini nisu isplaćivala sva društva, već samo pojedina (www.skdd.hr):

- Atlantic Grupa d.d. – 12,00 kn isplaćeno 15.07.
- Ericsson Nikola Tesla d.d. – 54,33 kn isplaćeno 19.06.
- Hrvatski Telekom d.d. – 7,00 kn u isplaćeno 25.05.
- INA – indrustrija nafte d.d. – 15,00 kn isplaćeno 08.07.
- Končar – Elektroindustrija d.d. – 12,00 kn isplaćeno 19.06.
- Kraš d.d. – 10,00 kn isplaćeno 28.10.
- Ledo d.d. – 214,85 KN isplaćeno 23.09.
- Valamar Riviera d.d. – 0,18 kn isplaćeno 07.07.
- Zagrebačka banka d.d. – 3,60 kn isplaćeno 20.05.

Iz tablice 5. može se iščitati da su najveće stope prinosa postigla upravo ona društva koja su u prethodnoj tablici postigla najniže vrijednosti: Ingra d.d., Ot – Optima Telekom d.d. i Dalekovod d.d., a najniže stope prinosa imaju ona društva koja su u prethodnoj tablici postigla najviše vrijednosti: Ledo d.d., INA d.d. i Ericsson Nikola Tesla d.d.

U 2015. godini Ingra d.d. ima stopu prinosa 36,54%, Ot – Optima Telekom d.d. 32,10%, a Dalekovod d.d. 17,41%. S druge strane, za istu godinu društvo Ledo d.d. ima stopu prinosa 0,11%, INA d.d. 0,23%, a Ericsson Nikola Tesla d.d. ima 0,60%. Prikazanim podacima vidljivo je 2015. godine da nije došlo do većeg pomaka u odnosu na 2014. godinu, te da su najvišu i najnižu stopu prinosa postigla ista društva. U nastavku rada biti će prikazani podaci društva koji ulaze u uzorak uz pripadajuće vrijednosti dobivene radom u Excelovom dodatku „Solver“.⁵

⁵ „Solver“ je Excelov alat koji daje ciljane rezultate iz svog modela pa je kao takav izuzetno koristan u financijskom menadžmentu.

5.2. REZULTATI EMPIRIJSKOG TESTIRANJA

Uzorak je stvoren korištenjem Excelovog dodatka „Solver“ unutar kojega su postavljena određena ograničenja. Zadana je naredba da prilikom stvaranja efikasnog portfelja minimalni udio svake dionice može postizati vrijednost 0%. Isto tako, u uzorak nisu ulazile one dionice kojima se nije trgovalo svih 53 tjedna u 2015-oj godini, te su tako iz početnog uzorka od 22 dionice izbačene sljedeće dionice: INA d.d., Ledo d.d., Podravka d.d., Tankerska Next Generation d.d. i dionice Zagrebačke banke d.d., i tako je stvoren portfelj sačinjen od 17 dionica. U sljedećoj tablici biti će prikazani postotni udjeli svake pojedine dionice u portfelju.

Analizirajući tablicu 6. moguće je primjetiti da najveći udio u portfelju za očekivanu stopu prinosa od 15% zauzimaju dionice Arenaturist – a d.d. sa 50,77% pri standardnoj devijaciji od $\pm 13,69\%$ i Maistra d.d. sa 24,13% pri istoj standardnoj devijaciji. Udjeli navedenih dionica u portfelju se povećavaju kako se povećava i razina standardne devijacije. S druge strane, najmanje udjele u portfelju imaju dionice Ot – Optima Telekom – a d.d. sa 0,24% i Atlantic Grupa d.d. sa 1,10% udjela pri istoj standardnoj devijaciji, ne uzimajući u obzir one dionice čiji je udjel 0%. Sukladno tome, promjenama standardne devijacije došlo je i do promjena varijanci i udjela dionica u portfelju.

Moguće je zaključiti da dionice iz odabranog portfelja ostvaruju pozitivne stope udjela, osim sljedećih društva: Atlantska plovidba d.d., Ericsson Nikola Tesla d.d., Ingra d.d., Kraš d.d., Luka Rijeka d.d. i Valamar Riviera d.d. Pregledom dionica Hrvatskog Telekoma vidljivo je da pri standardnoj devijaciji od $\pm 2,25\%$ ostvaruju udjel u portfelju od 2,32%, međutim kako se rizik portfelja i očekivana stopa prinosa povećavaju njihov udjel u portfelju sveden je na nulu.

Tablica 6.

Udjeli dionica u portfelju nakon korekcije Solverom za 2015. godinu

RB	DIONICA	UDJEL			
		2% povrat	5% povrat	10% povrat	15% povrat
1	ADPL-R-A	0,84%	2,21%	2,82%	3,05%
2	ARNT-R-A	38,85%	46,56%	49,61%	50,77%
3	ATGR-R-A	9,98%	4,65%	2,18%	1,10%
4	ATPL-R-A	0%	0%	0%	0%
5	BLJE-R-A	2,63%	1,89%	1,52%	1,41%
6	DDJH-R-A	6,75%	8,36%	9%	9,23%
7	DLKV-R-A	1,55%	1,36%	1,25%	1,21%
8	ERNT-R-A	0%	0%	0%	0%
9	HT-R-A	2,32%	0%	0%	0%
10	INGR-R-A	0%	0%	0%	0%
11	KOEI-R-A	12,67%	6,93%	4,21%	3,30%
12	KRAS-R-A	0%	0%	0%	0%
13	LKRI-R-A	0%	0%	0%	0%
14	MAIS-R-A	16,87%	21,52%	23,43%	24,13%
15	OPTE-R-A	1,58%	0,77%	0,39%	0,24%
16	RIVP-R-A	0%	0%	0%	0%
17	VART-R-A	5,95%	5,74%	5,58%	5,55%
σ		$\pm 0,02245$	$\pm 0,04835$	$\pm 0,09254$	$\pm 0,13694$

Izvor: izračun autora

Prikazani podaci iz tablice 6. postignuti su uz pomoć Excelovog dodatka „Solver“ kroz nekoliko koraka. Na početku treba napraviti tablicu u kojoj su unesene završne tjedne cijene odabranih 17 društva kroz 53 promatrana tjedna iz uzorka preuzete sa stanice Zagrebačke burze. Potom se pomoću jednadžbe (1) pretvaraju završne cijene u povrate za iste, uzimajući završnu cijenu dionice iz drugog tjedna i dijeleći je sa završnom cijenom dionice prvog tjedna i tako sve do zadnjeg očitavanja. Taj je postupak potrebno ponavljati sve dok se ne izračunaju povrati svih dionica za sve tjedne unutar godine dana. Nakon toga nastavlja se s izračunom prosjeka svih povrata za svaku dionicu pojedinačno te tako nastupa sljedeći korak.

Nadalje, pomoću dobivenih podataka kreće se s računanjem matrice varijanci – kovarijanci. U odnos je stavljena razlika opažanja jednog povrata i prosjeka svih povrata za pojedinu dionicu, te tako za sve dionice iz uzorka. U sljedećem koraku potrebno je označiti navedenu matricu kako bi ju Excel prepoznao kao skup podataka, a ne svaku vrijednost pojedinačno. Kada je stvorena matrica varijanci – kovarijanci, tada je moguće nastaviti sa izračunom varijance portfelja. U ovom koraku izračunavaju se i povrat i varijanca cijelog portfelja, ali pritom je potrebno imati na umu da bi se isti izračunali treba uzeti u obzir i težinu dionica u portfelju. Budući da je u analiziranom uzorku uključeno 17 dionica, težina svake dionice je iznosila $1/17$ ili 5,88% te su tako uključene sve dionice unutar portfelja u jednakom omjeru, a njihova optimizacija će nastupiti malo kasnije.

Da bi se izračunao prinos portfelja prvo treba kopirati sve prosječne povrate u novu odvojenu kolonu koja je nazvana „Means“, te pokraj nje je potrebno imenovati još pet kolona sa nazivima: „Weights“, „Ones“, „Constraint“, „Portreturn“ i „Portvar“. U koloni „Weights“ unose se gore navedene težine koje će kasnije Solver korigirati, u sljedećoj koloni se upisuju jedinice za sve dionice koje su u uzorku, a za preostale tri kolone se ponovno koriste matematičke i statističke funkcije koje Excel sadrži te se tako dolazi do izračuna njihovih vrijednosti. Nakon svega navedenog kreće se s korištenjem Excelovog dodatka – „Solver“. Sada je potrebno dodati još samo jednu kolonu koja se naziva „Portstd“, u kojoj će se izračunati standardna devijacija portfelja za dani prinos i ostatak rada Solver računa sam, jedino se dodaju ograničenja ovisno o onome što želimo izračunati. Glavno ograničenje je bilo da sve dionice u portfelju mogu postići minimalni udio od 0%. Zatim sa mijenjanjem razine traženog povrata (u postocima) iz kolone „Portreturn“ automatizmom Solver mijenja i ostale kolone koje sada postižu nove vrijednosti pomoću kojih je moguće pronaći efikasnu granicu za određeni portfelj, pa bi to u konačnici trebalo izgledati kao u sljedećoj tablici.

Tablica 7.

Utjecaj povrata i standardne devijacije na promjene udjela dionica u portfelju


	MEANS	WEIGHTS
ADPL	-0,00032	0,275069533
ARNT	0,01812	4,581182753
ATGR	-0,00057	0,099404604
ATPL	-0,00362	-1,14374105
BLJE	0,00784	0,127046526
DDJH	0,00655	0,833228457
DLKV	-0,00937	0,109199657
ERNT	-0,00657	-0,506672981
HT	-0,00314	-0,482947115
INGR	-0,01075	-0,052957702
KOEI	0,00038	0,298190186
KRAS	-0,00343	-2,70104175
LKRI	-0,01745	-0,626967723
MAIS	0,00883	2,176905669
OPTE	0,01115	0,021293413
RIVP	-0,00416	-2,508208444
VART	0,00388	0,501015967
	PORTRETURN	PORTSTD
	-0,00357	0,00798
	0,02000	0,02245
	0,05000	0,04835
	0,10000	0,09254
	0,15000	0,13694

Izvor: izračun autora

U tablici 7. prikazano je kako promjena povrata (u postocima) dionica utječe na izmjenu udjela pojedine dionice unutar portfelja. „Solver“ izračunava nove optimalne udjele umanjeanjem rizika portfelja za određenu traženu razinu povrata. Nakon što su podaci izračunati kao u gore prikazanoj tablici izrađuje se graf efikasne granice koji je prikazan u nastavku pomoću prethodno izračunatih rezultata. Na apscisi se nalazi rizik portfelja, a na ordinati je prikaz prinosa portfelja.

Graf 1.

Prikaz efikasne granice za odabrana društva, 2015. godina



Izvor: vlastita izrada

Promatrajući prethodni graf moguće je zaključiti da sve dionice iz odabranog uzorka ostvaruju pozitivne stope prinosa. Ako promatramo ovako prikazane dionice, njihove standardne devijacije i stope prinosa sa prethodno izračunatim konačnim udjelima dionica u portfelju može se zaključiti da ulaganje u veći skup dionica nosi manji rizik nego ulaganje u pojedinu dionicu. Iako neke dionice ostvaruju velike stope povrata (pri većim rizicima), ulaganje u portfelj je kvalitetnija i racionalnija odluka budući da se pri minimalnom riziku stvara manji gubitak nego li ulaganjem u pojedinačne vrijednosnice, pogotovo kada nekolicina vrijednosnica ima negativne stope povrata.

6. ZAKLJUČAK

Kroz ovaj rad definiran je pojam portfelja i nekih elemenata koji utječu na stvaranje i upravljanje istog. Empirijskom analizom dokazano je da vrijedi diverzificirati i da je Markowitzev model primjenjiv na hrvatskom tržištu kapitala te da je moguće stvoriti optimalan portfelj. Iako Markowitzev model sadrži neke nedostatke, kvalitetnijom analizom moguće ga je prilagoditi uvjetima hrvatskog tržišta kapitala, uzimajući u obzir tržišni rizik i likvidnost, odnosno nelikvidnost dionica na domaćem tržištu kapitala.

Pronalazak efikasne granice i stvaranje efikasnog portfelja je od velike značajnosti za svakog investitora neovisno o njegovim sklonostima. Cilj je stvoriti portfelj koji će donositi najveću korisnost za njegovog vlasnika. Isto tako, važno je biti svjestan da se prilikom trgovanja dionicama uvijek pojavljuju određeni rizici. Ako je na njih moguće utjecati, odnosno ako ih je moguće predvidjeti onda je jednostavnije nositi se sa situacijom jer će diverzifikacija portfelja uvelike pomoći, međutim kada se radi o tržišnom riziku tu je već puno teže utjecati jer on ovisi o kretanju vrijednosnica na ukupnom tržištu kapitala.

Analizom trgovanja dionicama CROBEX – a preuzetih sa stranice Zagrebačke burze neke od dionica su morale radi slabije likvidnosti biti izuzete iz uzorka. Isto tako, u uzorku određene dionice su ostvarivale negativne stope povrata. Opći zaključak je da se ulaganjem u portfelj umanjuje ukupan rizik te je tako lakše ostvariti veći prinos. Iako bi se pojedinačnim ulaganjem u neke dionice mogao ostvariti veći prinos (poput dionica Arenaturista d.d.), takva ulaganja su u pravilu rizičnija. Pretpostavljajući da većina investitora nije sklona riziku, ulaganje u portfelj se pokazalo kao bolji izbor budući da je manje rizično. Važno je imati na umu da se pri formiranju portfelja treba provesti kvalitetna analiza financijskih pokazatelja, te da je bitno kombinirati statističke i matematičke metode sa kretanjem na tržištu kako bi se mogle donijeti čim kvalitetnije investicijske odluke.

LITERATURA

Knjige

- ALJINOVIĆ, Z., MARASOVIĆ, B. i ŠEGO, B. (2008.) Financijsko modeliranje. Zagreb – Split: Zgombić i Partneri
- BREALEY, R.A., MYERS, S.C. i MARCUS, A.J. (2007.) Osnove korporativnih financija. Zagreb: Mate d.o.o.
- MARKOWITZ, H. M. (1959.) Portfolio Selection: Efficient Diversification of Investments. New York: John Wiley & Sons
- ORSAG, S. (2015.) Investicijska analiza. Zagreb: Avantis
- TOMIĆ – PLAZIBAT, N., ALJINOVIĆ, Z. i MARASOVIĆ, B. (2006.) Matematički modeli u financijskom upravljanju. Split: Ekonomski fakultet Split
- VAN HORNE, J.C. i WACHOWICZ JR., J.M. (2002.) Osnove financijskog menadžmenta. Deveto izdanje. Zagreb: Mate d.o.o.
- VIDUČIĆ, LJ. (2006.) Financijski menadžment. V. dopunjeno i izmijenjeno izdanje. Zagreb: RRiF – plus

Članci

- JERONČIĆ, M i ALJINOVIĆ, Z. (2011.) Formiranje optimalnog portfelja pomoću Markowitzevog modela uz sektorsku podjelu kompanija. *Ekonomski pregled*. 62 (9 – 10) str. 583 – 606
- JAKŠIĆ, S. (2007.) Primjena Markowitzeve teorije na tržište dionica Zagrebačke burze. Zagreb: Zbornik Ekonomskog fakulteta u Zagrebu: Ekonomski fakultet Zagreb. 5(1) str. 331 – 344

Ostali izvori

- RAIĆ, K. (2015.) Markowitzeva optimizacija portfolija [online] Repozitorij. Ekonomski fakultet Zagreb. Dostupno na: <https://repozitorij.efzg.unizg.hr/islandora/object/efzg%3A263/datastream/PDF/view> [Pristupljeno 06.09.2015.]
- SKDD (Središnje klirinško depozitarno društvo), (2016.) Registri, korporativne akcije za 2016. godinu. Dostupno na: <http://www.skdd.hr/portal/f?p=100:41:0::NO:RP,41::> [Pristupljeno: 12.09.2015.]
- ZSE (Zagrebačka burza), (2016.) Sastav CROBEX – a u 2015. godini. Dostupno na: <http://zse.hr/default.aspx?id=44101&index=CROBEX> [Pristupljeno: 01.09.2015]

SAŽETAK

Adam Vukelić

Primjena MPT modela na hrvatskom tržištu kapitala

Markowitz je 1952. godine razvio model prema kojem je bilo moguće uravnotežiti prinos i rizik u određenoj kombinaciji vrijednosnica te je za taj rad dobio Nobelovu nagradu. Opisao je važnost diverzifikacije u portfelju kako bi se umanjio rizik svake pojedine vrijednosnice. Racionalni investitori žele postići viši prinos uz preuzimanje manjeg rizika pa tako ulažu u različite imovine različitih grana industrije i na taj način diverzificiraju. Kod ulaganja u dionice investitori trebaju pratiti kretanje stope prinosa na dionicu kako bi mogli kvalitetnije procijeniti dionicu ili portfelj u koji žele uložiti. Ulaganje u portfelj (skup vrijednosnica) je puno sigurnije od ulaganja u samo jednu vrijednosnicu. Investitorov cilj je pronalazak optimalnog portfelja koji je smješten na efikasnoj granici u točki gdje se ostvaruje najveći mogući prihod uz preuzimanje određene razine rizika. Empirijskim istraživanjem dokazano je da se Markowitzev model može uspješno primjeniti na hrvatskom tržištu kapitala, te da sve dionice iz odabranog uzorka ostvaruju pozitivne stope povrata iako određene dionice pri zadanim stopama rizika ne ostvaruju udjel u portfelju.

Ključne riječi: diverzifikacija, rizik, efikasna granica, optimalan portfelj

SUMMARY

Adam Vukelić

MPT model usability on Croatian capital market

In 1952 Markowitz has developed a model that made it possible to balance incomes and risks in a particular combination of securities and for that work he received the Nobel prize. He described the importance of diversification in the portfolio in order to minimize risks of any particular securities. Rational investors are looking to achieve a higher return while taking less risks and so they invest in different assets of various industries and that's how they are using diversification. While investing in stocks, investors need to monitor the movement of the rate of return on the stock in order to make a better assessment of stocks or a portfolio in which they want to invest. Investing in a portfolio (a collection of securities) is much safer than investing in a single security. Investors are trending to find the optimal portfolio which is located on the efficient frontier in a place where it achieves maximum income while assuming a certain level of risk. Empirical research has shown that the Markowitz model can be successfully applied on the Croatian capital market and that all the shares of the selected sample achieved positive rates of return, although some stocks with the certain rate of risk do not accomplish a share in the portfolio.

Key words: diversification, risk, efficient frontier, optimal portfolio